

ML-Nachhaltigkeitstools

Erarbeitet von
Marc Feger M.Sc.

Lernziele	1
Inhalt	2
Einstieg	2
Soziale Nachhaltigkeit	2
Ökologische Nachhaltigkeit	2
Beispielverbrauch zum Training von BERT	3
Ökonomische Nachhaltigkeit	4
Zusammenfassung	4
Quellen	4
Weiterführendes Material	5
Disclaimer	5

Lernziele

- Du lernst die drei Hauptbereiche der Nachhaltigkeit in der KI kennen
- Du weißt, welche Tools zur Bestimmung des CO₂-Verbrauchs von ML-Modellen verfügbar sind
- Du verstehst, dass Nachhaltigkeit im Umgang mit Künstlicher Intelligenz keine Option, sondern eine Notwendigkeit ist

Inhalt

Einstieg

Willkommen zu unserem heutigen Video,

in dem wir uns den verschiedenen Aspekten der Nachhaltigkeit in der Künstlichen Intelligenz widmen. Künstliche Intelligenz (KI) ist ein weitreichendes Feld mit Einflüssen auf viele Bereiche unseres Lebens, und es ist entscheidend, diese Technologie aus einer nachhaltigen Perspektive zu betrachten.

Die Nachhaltigkeit in der Künstlichen Intelligenz lässt sich grob in drei Kernbereiche gliedern.

Soziale Nachhaltigkeit

Quelle [1]

Beginnen wir mit der sozialen Nachhaltigkeit. Dieser Bereich erforscht, wie Künstliche Intelligenz und Gesellschaft miteinander interagieren. Die Kernfrage dabei lautet: „Welche Rolle spielt KI in unserem sozialen Gefüge?“ Hier konzentrieren wir uns auf die sozialen Aspekte der KI, die sich vor allem auf die Wahrung der menschlichen Würde und Autonomie beziehen. Dies umfasst die Förderung von Vielfalt, die Berücksichtigung grundlegender menschlicher Bedürfnisse und Lebensumstände sowie den Schutz besonders vulnerabler Gruppen. Ein Beispiel für negative Auswirkungen in diesem Bereich ist der Aufbau eines digitalen Überwachungsstaates, wie er in einigen Ländern zu finden ist, oder die Verbreitung von Hassreden gegen Minderheiten in sozialen Netzwerken.

Ökologische Nachhaltigkeit

Quelle [1, 2, 3, 4, 6]

Der nächste Punkt unserer Betrachtung ist die ökologische Nachhaltigkeit der Künstlichen Intelligenz. Diese Perspektive beleuchtet, wie KI innerhalb der Grenzen unseres Planeten operieren kann, um zukünftigen Generationen einen sicheren Lebensraum zu gewährleisten und irreversible Schäden an der Umwelt zu verhindern. Ein wesentlicher Aspekt hierbei ist das Bewusstsein über den Ressourcenverbrauch, der mit der Entwicklung und Anwendung von KI einhergeht. Insbesondere das Betreiben von GPU-Servern für das Training von KI-Modellen stellt einen signifikanten Verbrauch dar.

Es ist von entscheidender Bedeutung, dass wir die ökologischen Auswirkungen der Künstlichen Intelligenz ernst nehmen und Wege finden, diese Technologie nachhaltig zu gestalten. Dies umfasst die Suche nach energieeffizienteren Methoden für das Training und den Betrieb von KI-Systemen, um so den ökologischen Fußabdruck zu minimieren und sicherzustellen, dass wir die planetaren Grenzen respektieren.

Um den CO₂-Ausstoß während des Trainings von KI-Modellen zu berechnen, existieren bereits mehrere Ansätze:

Ein wesentlicher Schritt in Richtung einer nachhaltigeren KI ist die Aufklärung über den Ressourcenverbrauch. Unternehmen wie Amazon gehen hier mit gutem Beispiel voran, indem sie Richtlinien zur Optimierung von AI/ML-Workloads in Bezug auf Nachhaltigkeit bereitstellen. Dazu zählt die kritische Bewertung, ob Maschinelles Lernen (ML) die geeignete Lösung für eine bestimmte Aufgabe ist, die Nutzung von KI-Diensten und vortrainierten Modellen wie BERT, sowie die Auswahl von Speicheroptionen, die eine geringere Umweltbelastung mit sich bringen. AWS legt außerdem nahe, bestehende öffentlich verfügbare Datensätze zu verwenden, um unnötige Duplikationen in der Datenverarbeitung zu vermeiden, und empfiehlt die Verwendung serverloser Architekturen für Datenpipelines, um Ressourcen zu sparen, die nicht durchgehend benötigt werden.

Ein weiterer Ansatz zur Verringerung des ökologischen Fußabdrucks ist die Überwachung und Reduzierung des CO₂-Ausstoßes während des Trainings von Modellen. Tools wie CodeCarbon, ein Python-Paket, ermöglichen es, die CO₂-Emissionen von Computerprogrammen, einschließlich tiefer neuronaler Netzwerke, zu verfolgen. Dies geschieht durch Berücksichtigung verschiedener Faktoren wie Computerinfrastruktur, Standort, Nutzung und Laufzeit, um eine Schätzung des CO₂-Ausstoßes zu liefern. Interessanterweise bietet CodeCarbon auch Vergleiche mit gängigen Transportmodi an, um die Größenordnung der Emissionen zu veranschaulichen.

Da der CO₂-Verbrauch durch KI erst in den letzten Jahren zunehmend in den Fokus gerückt ist, wurden spezialisierte Tools wie ML CO₂ IMPACT entwickelt, die auf CodeCarbon basieren. Diese Tools ermöglichen es, die CO₂-Emissionen nach Abschluss des Trainingsprozesses zu berechnen, basierend auf Daten wie Standort und GPU-Typen. Plattformen wie Hugging Face empfehlen die Nutzung dieser Tools, um Modellbeschreibungen mit Informationen zum CO₂-Verbrauch zu versehen und so die Transparenz und Verantwortung im Bereich der KI-Nachhaltigkeit zu erhöhen.

Beispielverbrauch zum Training von BERT

Quelle [4, 5]

Als Beispiel sei genannt, dass für das Training des BERT-Modells ursprünglich kein CO₂-Verbrauch dokumentiert wurde. Dennoch ist bekannt, dass das Training des BERT-base-Modells auf 4 Cloud TPUs in einer Pod-Konfiguration (insgesamt 16 TPU-Chips) erfolgte, während für BERT-large 16 Cloud TPUs (64 TPU-Chips) eingesetzt wurden, wobei jedes Trainingsset 4 Tage in Anspruch nahm.

Geht man davon aus, dass BERT-base auf einem TPuv2-Chip in der Google Cloud Region Asien-Ost1 für insgesamt 96 Stunden mit einer CO₂-Effizienz von 0,56 kg CO₂ pro kWh betrieben wurde, errechnen sich daraus geschätzte Gesamtemissionen von 11,88 kg CO₂ je TPU. Dies lässt sich umrechnen in eine Fahrtstrecke von 48 km mit dem ICE, den Verbrauch von 5,95 kg Kohle oder die CO₂-Aufnahme von 0,2 Baumsetzlingen über einen Zeitraum von 10 Jahren.

Hochgerechnet auf vier TPUs resultiert dies in Emissionen von 47,52 kgCO₂eq, was gleichzusetzen ist mit 192 km ICE-Fahrt, 23,8 kg verbrannter Kohle oder dem CO₂-Bindungsvermögen von etwa einem Baumsetzling über ein Jahrzehnt.

Bis Anfang Januar 2024 wurde das BERT-base-Modell 34.169.601-mal von Hugging Face heruntergeladen. Würde man unterstellen, dass für jeden dieser Downloads ein eigenes Training des BERT-base-Modells erfolgt wäre, statt auf die bereits trainierte Version zurückzugreifen, wäre die Anzahl der benötigten Baumsetzlinge, um den dadurch verursachten CO₂-Ausstoß zu neutralisieren, vergleichbar mit ca. 0,009 % der Fläche des Amazonasregenwaldes. Diese Betrachtung verdeutlicht die Bedeutung der Nutzung vortrainierter Modelle, um den ökologischen Fußabdruck von Maschinenlernprojekten zu minimieren.

Ökonomische Nachhaltigkeit

Quelle [1]

Schließlich runden wir unsere Betrachtung der Nachhaltigkeit mit dem Aspekt der ökonomischen Nachhaltigkeit ab. Diese Perspektive befasst sich mit einer Wirtschaft, die sich innerhalb der Grenzen des sozialen und ökologischen Rahmens bewegt, mit dem Ziel, ein Gleichgewicht zwischen diesen entscheidenden Bereichen zu finden.

Zusammenfassung

Ich hoffe, dieses Video hat dir wertvolle Einblicke in die vielfältigen Aspekte der Nachhaltigkeit im Bereich der Künstlichen Intelligenz gegeben.

Quellen

- Quelle [1] Institut für ökologische Wirtschaftsforschung (IÖW). (2021). Nachhaltigkeitskriterien für Künstliche Intelligenz. https://www.ioew.de/fileadmin/user_upload/BILDER_und_Downloaddateien/Publikationen/2021/IOEW_SR_220_Nachhaltigkeitskriterien_fuer_Kuenstliche_Intelligenz.pdf
- Quelle [2] Amazon Web Services. (2022). Optimize AI/ML workloads for sustainability: Part 1, identify business goals, validate ML use, and process data. <https://aws.amazon.com/de/blogs/architecture/optimize-ai-ml-workloads-for-sustainability-part-1-identify-business-goals-validate-ml-use-and-process-data/>
- Quelle [3] CodeCarbon. <https://mlco2.github.io/codecarbon/>
- Quelle [4] ML CO2 IMPACT. <https://github.com/GreenAlgorithms/green-algorithms-tool>
- Quelle [5] Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of Deep Transformers for Language Understanding. <https://arxiv.org/abs/1810.04805>

Quelle [6] Budenny, S.A., Lazarev, V.D., Zakharenko, N.N. et al. (2022). eco2AI: Carbon Emissions Tracking of Machine Learning Models as the First Step Towards Sustainable AI. <https://doi.org/10.1134/S1064562422060230>

Weiterführendes Material

Huggingface Model Cards <https://huggingface.co/docs/hub/model-cards-co2>

Carbontracker. <https://github.com/lfwa/carbontracker>

Experiment Impact Tracker. <https://github.com/Breakend/experiment-impact-tracker>

Green Algorithms Tool. <https://github.com/GreenAlgorithms/green-algorithms-tool>

Tracecarbon. <https://github.com/fvaley/tracarbon>

Carbontracker. <https://github.com/lfwa/carbontracker>

Disclaimer

Transkript zu dem Video „Themenblock 5 AI Literacy: KI & Ich 05_05Transfer_Nachhaltigkeitstools_MF“, Marc, Feger.

Dieses Transkript wurde im Rahmen des Projekts ai4all des Heine Center for Artificial Intelligence and Data Science (HeiCAD) an der Heinrich-Heine-Universität Düsseldorf unter der Creative Commons Lizenz [CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/) veröffentlicht. Ausgenommen von der Lizenz sind die verwendeten Logos, alle in den Quellen ausgewiesenen Fremdmaterialien sowie alle als Quellen gekennzeichneten Elemente.